

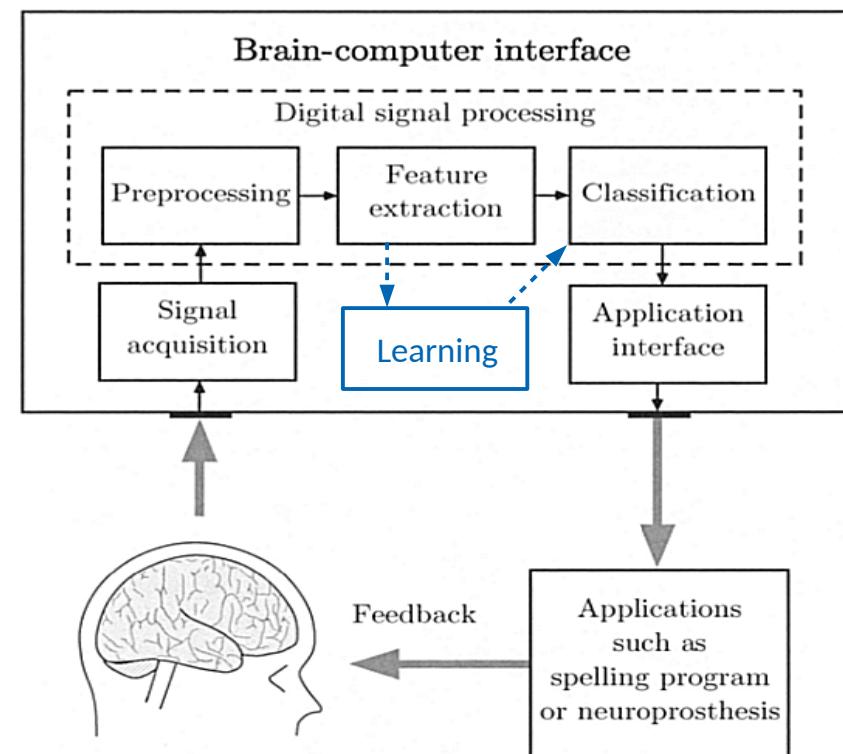


SPEKTRALNA ANALIZA IN PARAMETRIČNO MODELIRANJE

- Faze procesiranja signalov EEG med interakcijo možgani računalnik
- Izločanje značilk v frekvenčnem prostoru
- Primer diskretnega spektra
- Močnostni spekter
- Izločanje značilk v frekvenčnem prostoru
- Značilke v frekvenčnem prostoru
- Tipične arhitekture VMR
- Diskretna Fourierjeva transformacija (DFT)
- Časovno diskretna Fourierjeva transformacija (ČDFT)
- Določanje odziva LČN sistema v frekvenčni domeni
- Parametrično modeliranje (avtoregresivni AR parametri)

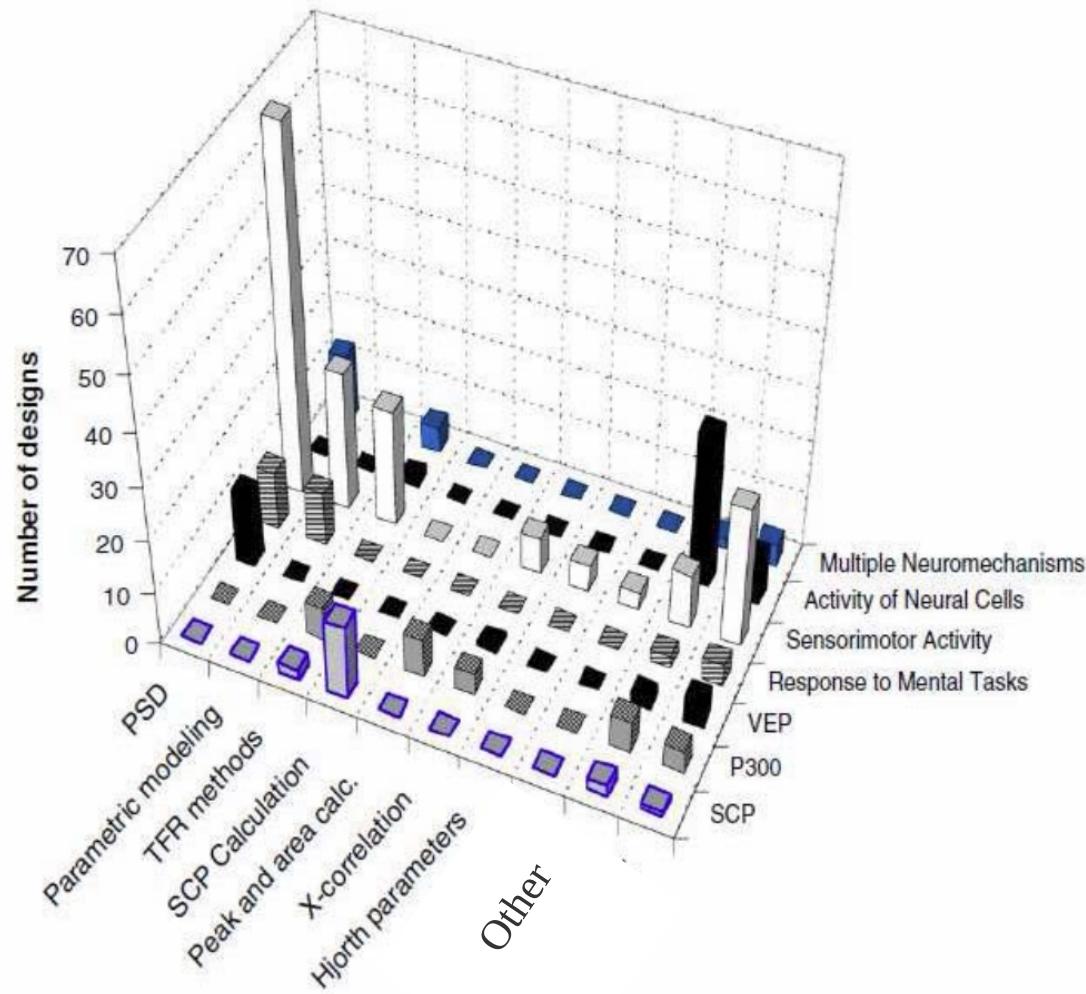
Faze procesiranja signalov EEG med interakcijo možgani računalnik

- **Zajemanje signalov:** EEG signali so dobljeni z možganov z uporabo invazivnih ali neinvazivnih metod (preko elektrod), signali so ojačeni in vzorčeni
- **Predobdelava:** čiščenje signalov (še posebno artefakti vsled utripanja oči) in filtriranje signalov
- **Izločanje značilk:** prostorske, časovne, časovno prostorske značilke in **značilke za ocenjevanje močnostnih spektrov**
- **Klasifikacija:** signali se procesirajo in klasificirajo z namenom ugotovitve katero vrsto mentalne naloge je subjekt opravljal
- **Interakcija z računalnikom** (vmesnik aplikacije, aplikacija): algoritem uporablja klasificirane signale za upravljanje določene aplikacije



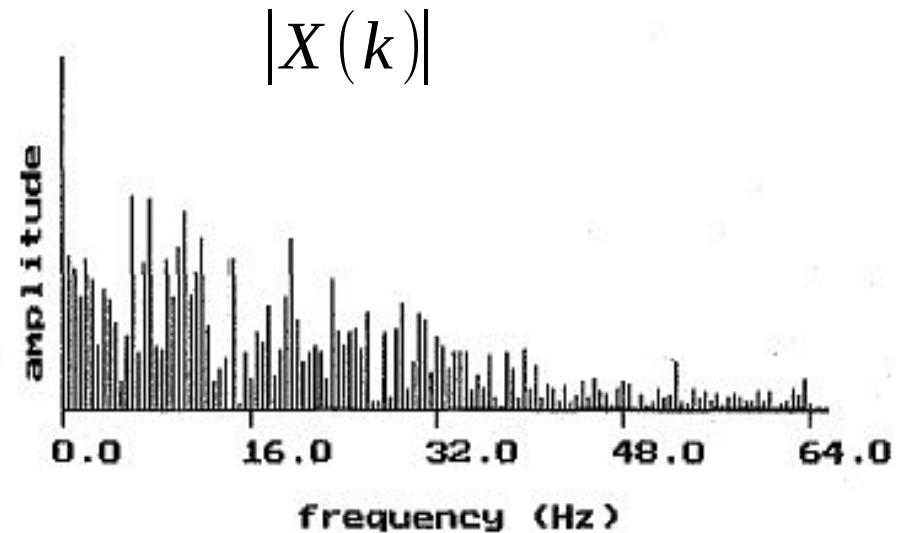
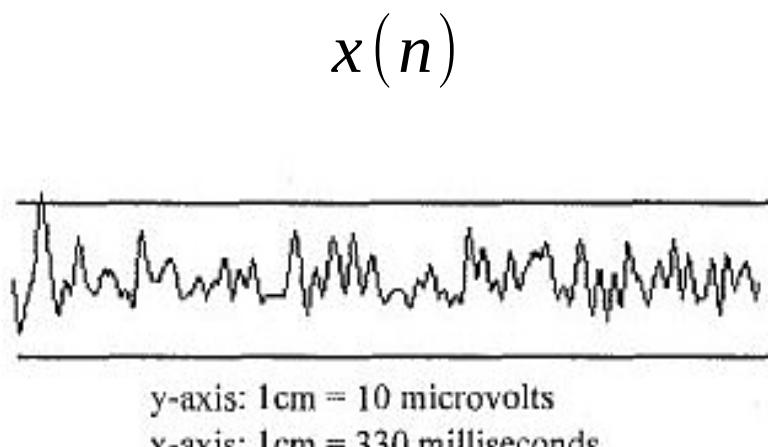
Izločanje značilk v frekvenčnem prostoru

- Tehnike izločanja značilk
 - Na osnovi spektra ali močnostnega spektra
(PSD - power-spectral density)
 - Parametrično modeliranje
(Parametric modeling)
 - Časovno frekvenčne predstavitev
(TFR - Time-frequency representation)
 - SCP – Slow cortical potentials
 - Peak and area calculation
 - Križna korelacija
X-correlation
 - Hjorth-ovi parametri
(Hjorth parameters)
 - Drugo



Primer diskretnega spektra

- Časovni signal, $x(n)$, in njegov spekter, $|X(k)|$, v frekvenčnem prostoru





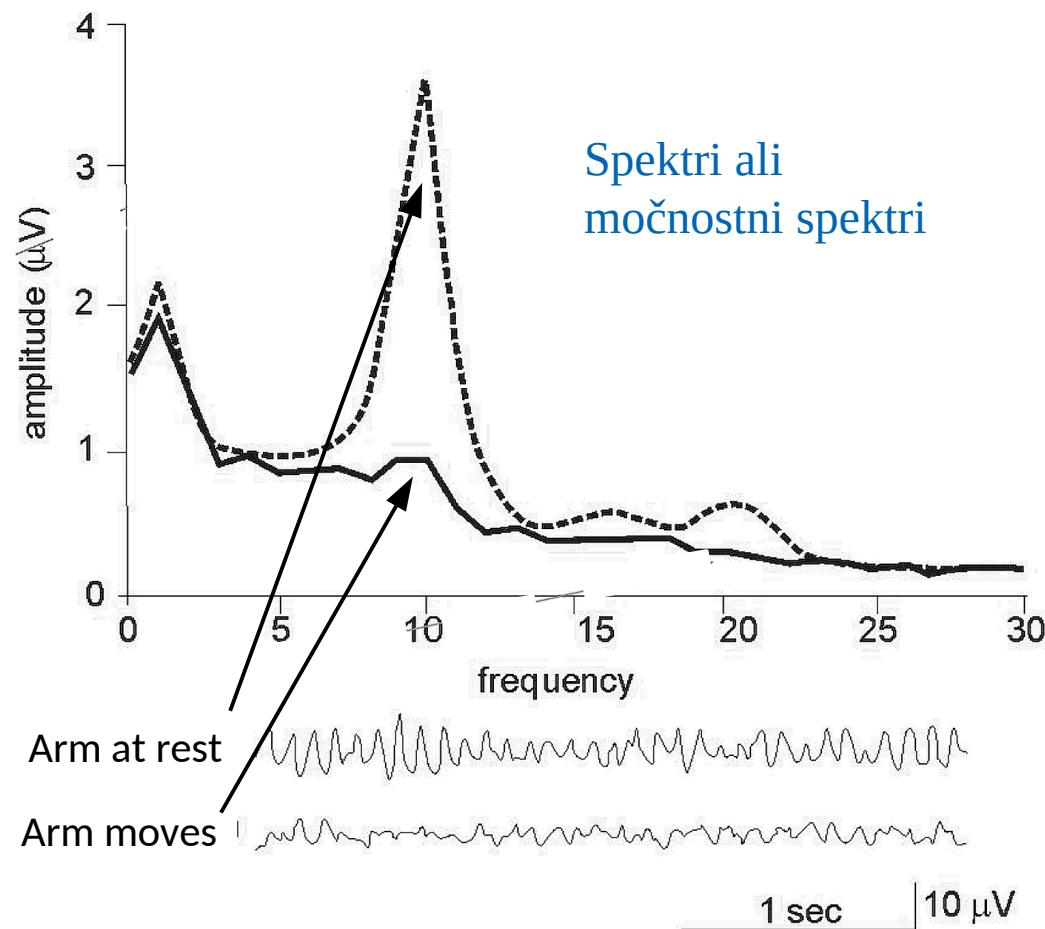
Močnostni spekter

- Ocenjeni močnostni spekter signala $x(n)$

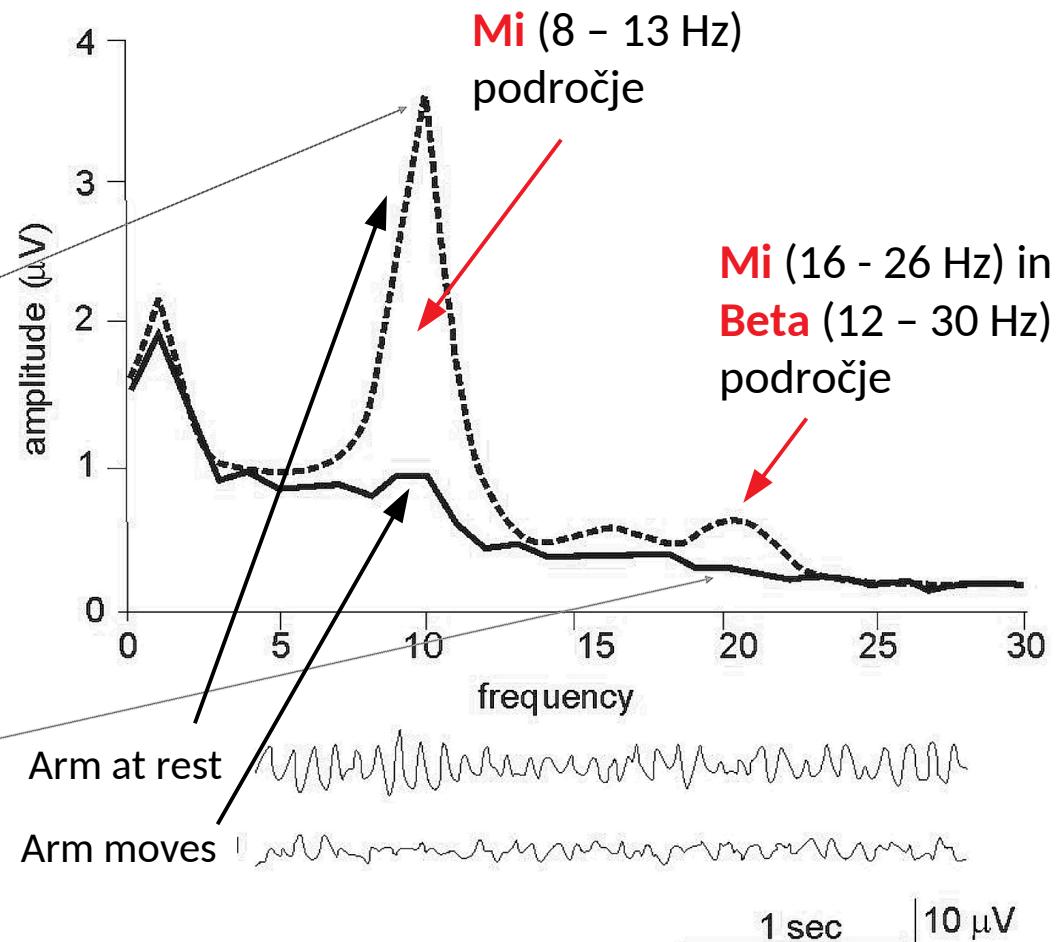
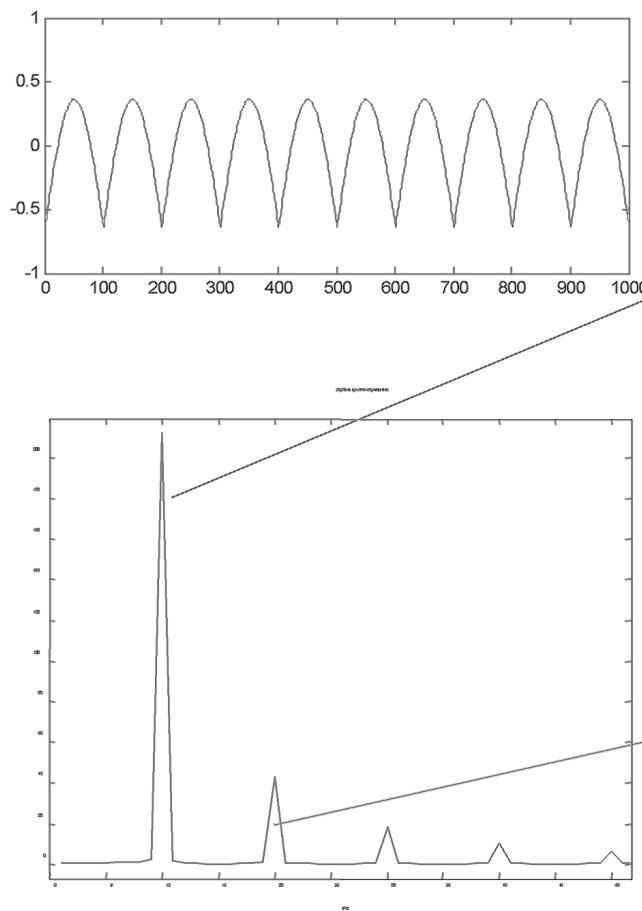
$$P(k) = |X(k)|^2 = \left| \sum_{n=0}^{N-1} x(n) e^{j(\frac{2\pi k}{N}) n} \right|^2$$

Izločanje značilk v frekvenčnem prostoru

- Tipične značilke (amplitude vrhov spektrov ali močnostnih spektrov signalov v Mi frekvenčnem področju, 8 – 13 Hz)
- Zamišljanje premika leve roke → premakni kurzor v levo
- Zamišljanje premika desne roke → premakni kurzor v desno

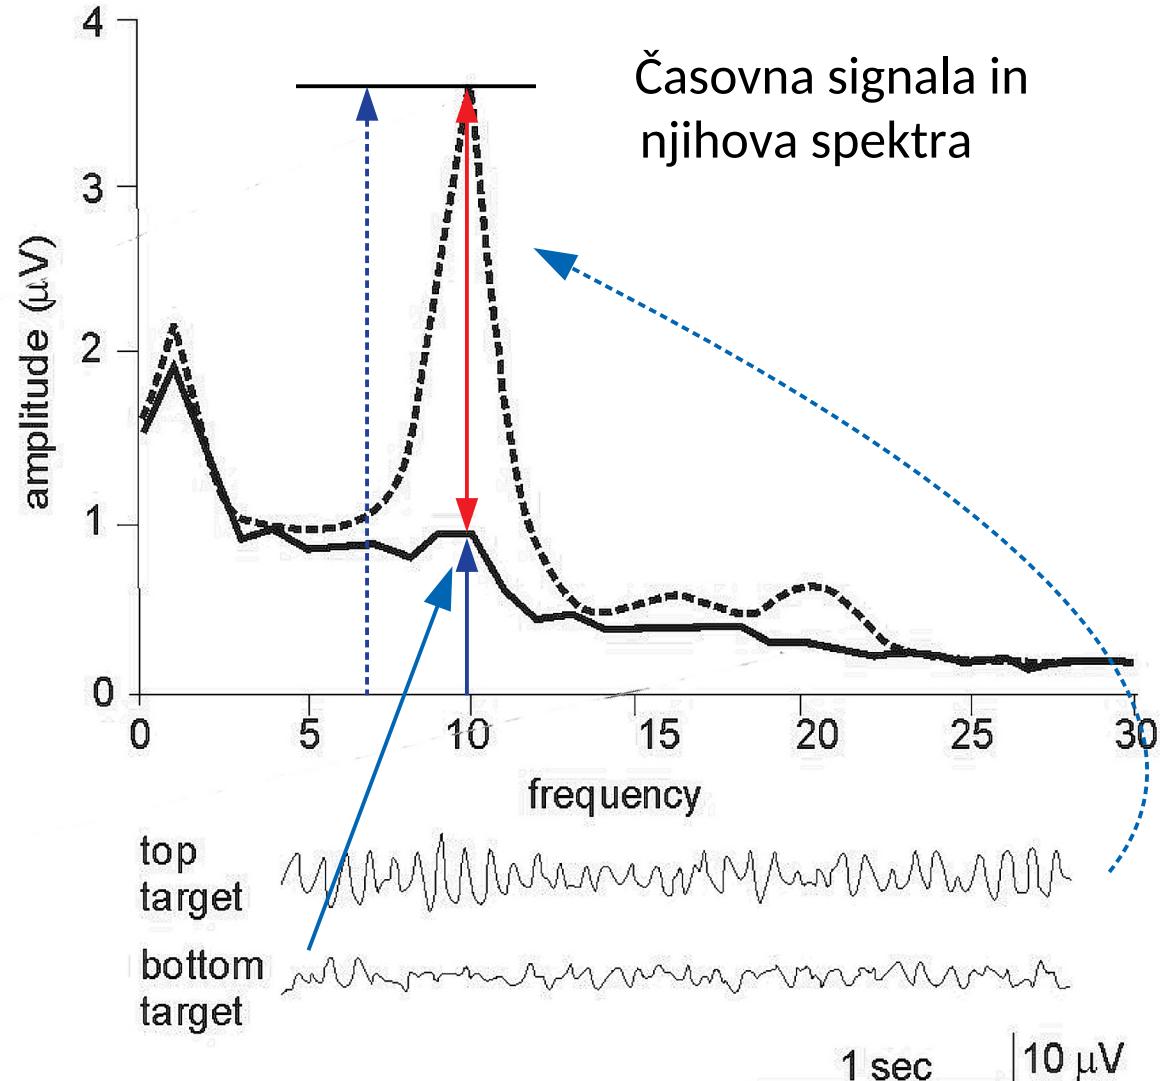


Izločanje značilk v frekvenčnem prostoru

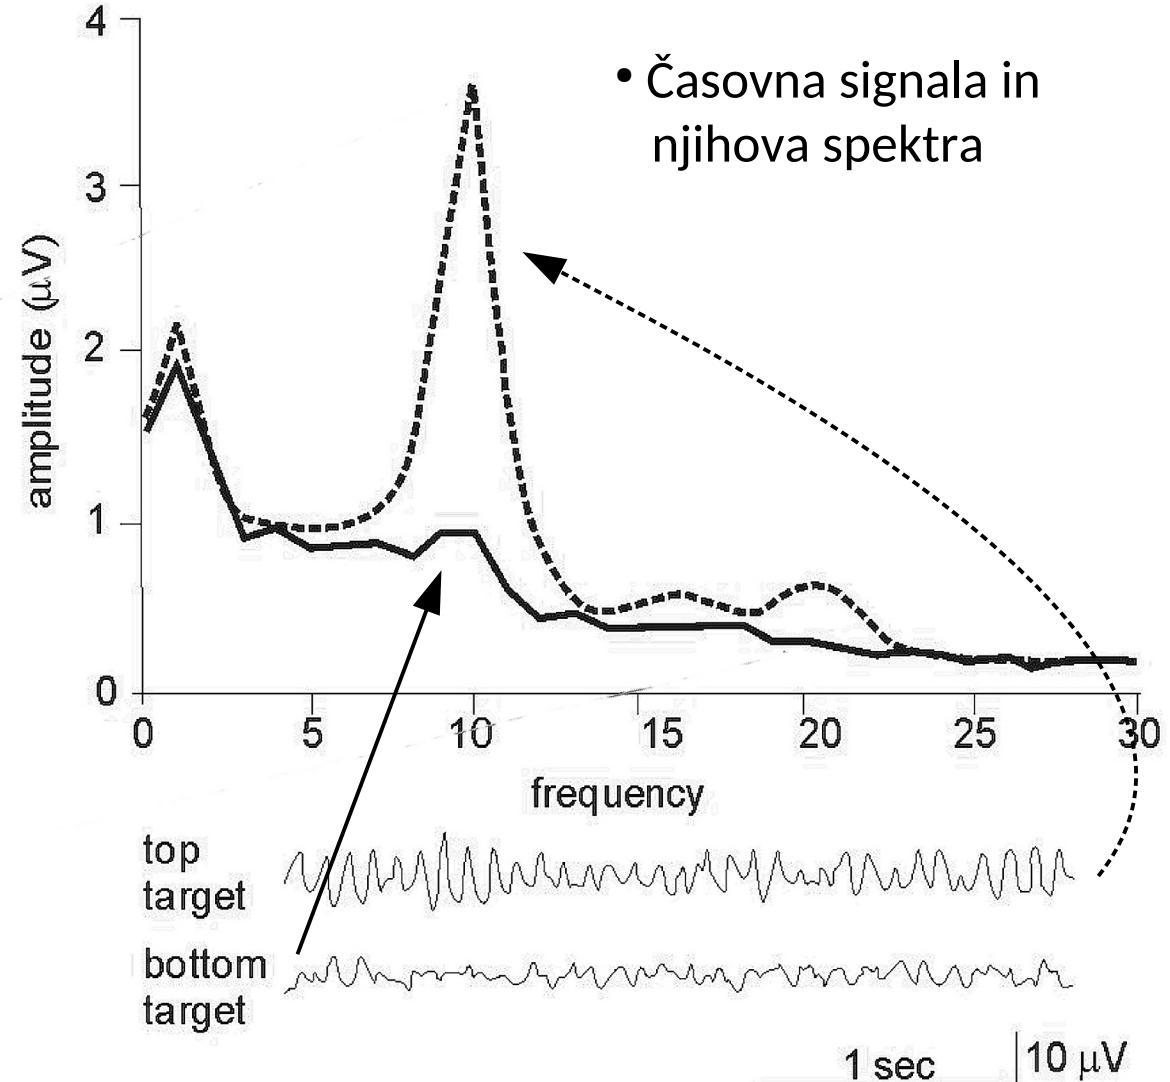
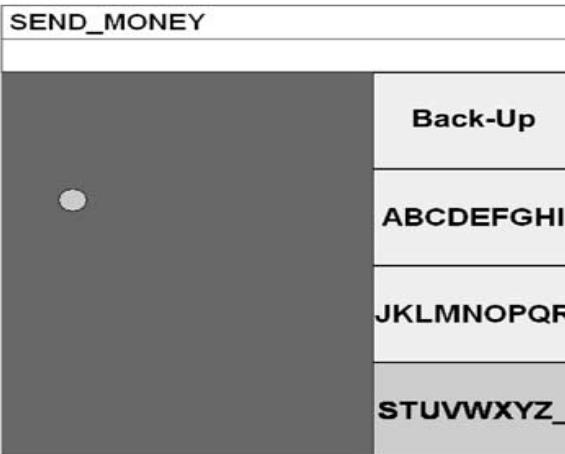


Značilke v frekvenčnem prostoru

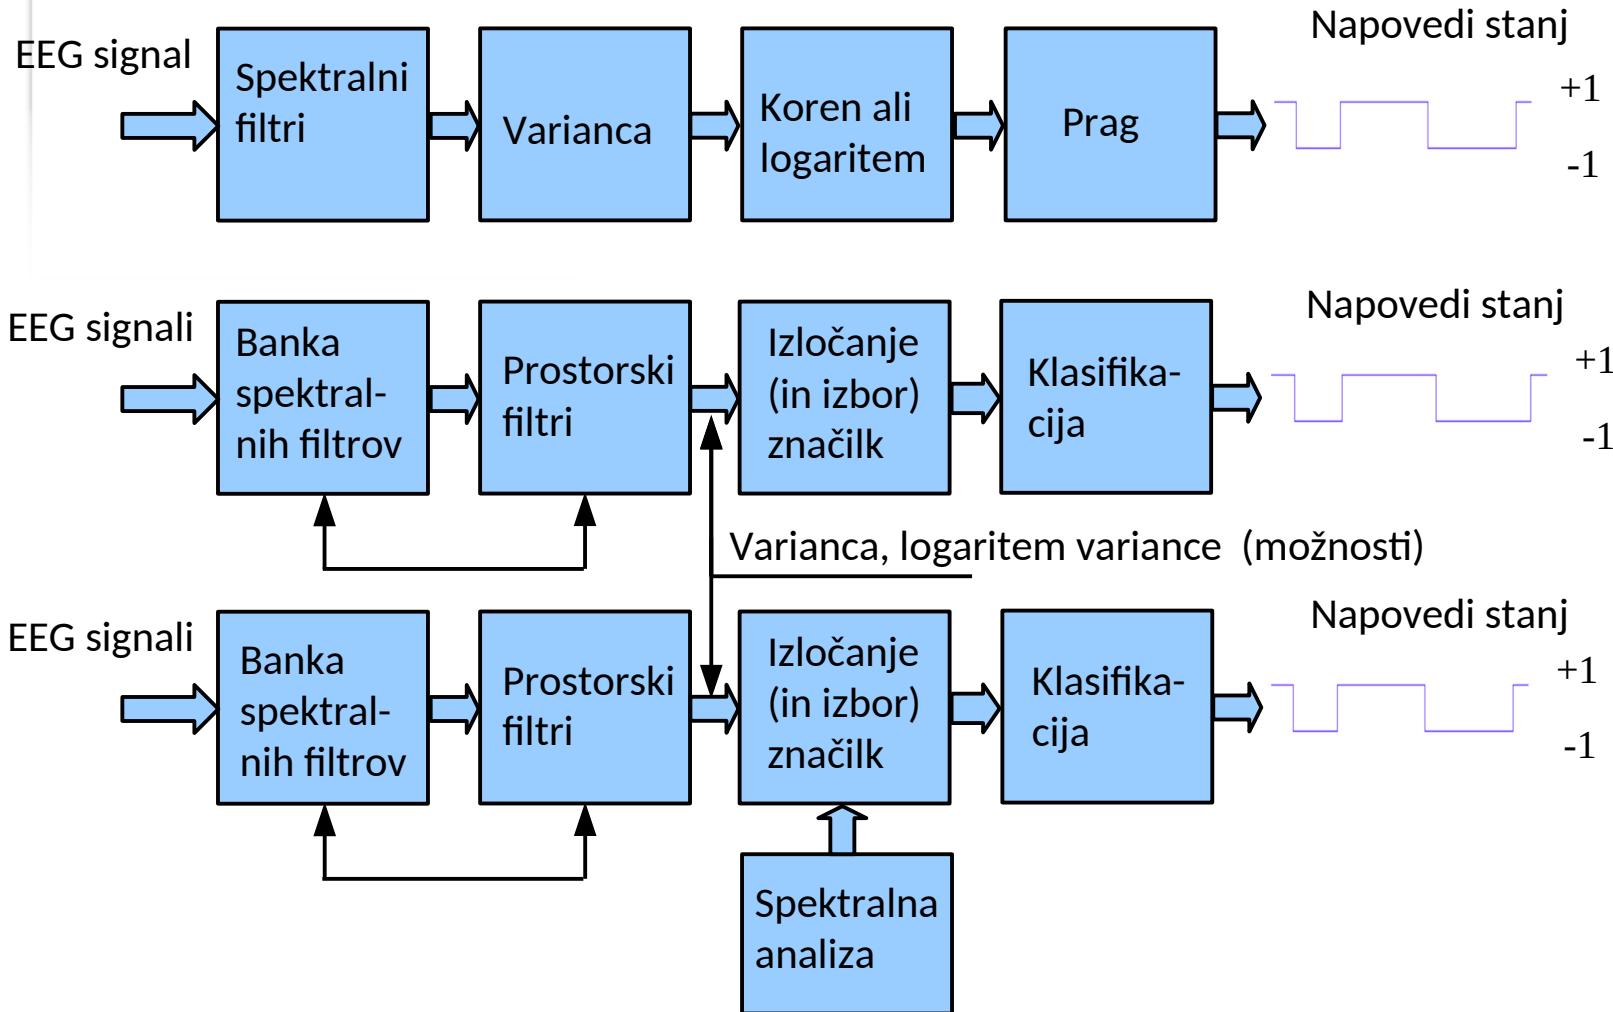
- Značilke so **amplitude spektrov ali močnostnih spektrov** v danem frekvenčnem področju, (npr. 8-13 Hz, μ ritem), ali **razlike amplitud** v danem frekvenčnem področju



Značilke v frekvenčnem prostoru



Tipične arhitekture VMR



Diskretna Fourierjeva Transformacija (DFT)

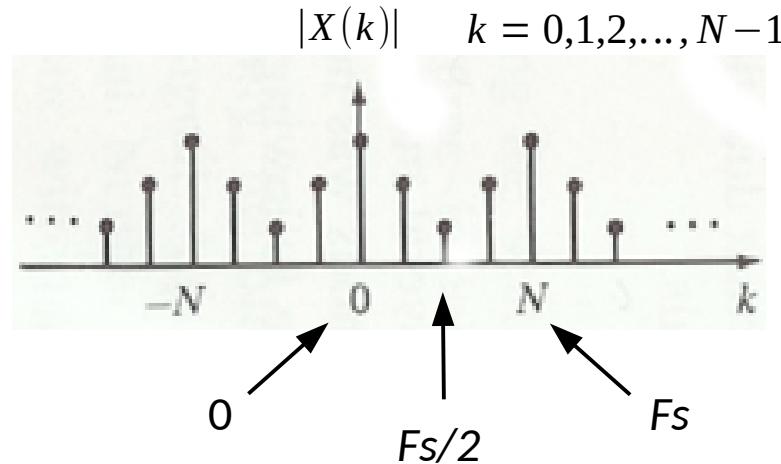
- DFT razdeli (vzorči) interval $0 .. F_s$ na N enakih intervalov za izračun $X(k)$

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-j(\frac{2\pi k}{N}) \cdot n}$$

$$X(k) = \sum_{n=0}^{N-1} \left(x(n) \cos\left(\frac{2\pi k}{N}n\right) - j x(n) \sin\left(\frac{2\pi k}{N}n\right) \right)$$

→ končna, diskretna
in periodična s
periodo N

Primer, $N = 4$



- F_s
 - Frekvenca vzorčenja
- $|X(k)|$
 - N vzorcev frekvenčnega spektra, $k = 0, 1, 2, \dots, N-1$
- $\Delta F = F_s / N$
 - Interval med dvema vzorcema v frekvenčnem spektru [Hz]
- $F_k = k \cdot \Delta F$
 - Frekvenca k -tega vzorca v frekvenčnem spektru [Hz]

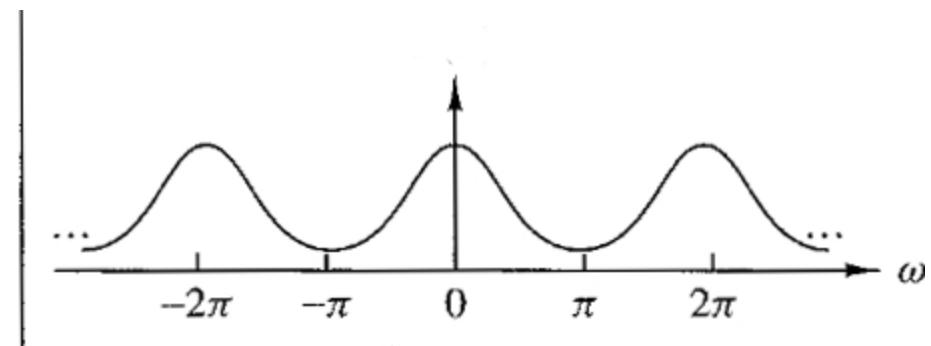
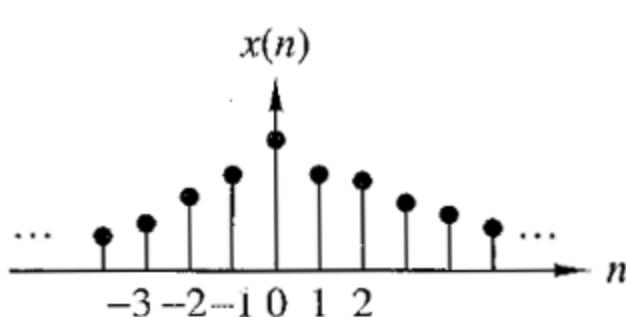
Časovno diskretna Fourierjeva transformacija (ČDFT)

- Časovno diskretna Fourierjeva transformacija (ČDFT, DTFT) signala $x(n)$

$$\text{DČFT: } X(e^{j\omega}) = \sum_{n=-\infty}^{\infty} x(n) e^{-jn\omega} \quad e^{-j\omega} = \cos(\omega) - j\sin(\omega)$$

$$\text{DFT: } X(k) \equiv X(e^{j\omega}) \Big|_{\omega_k = \frac{2\pi k}{N}} = \sum_{n=0}^{N-1} x(n) e^{-j(\frac{2\pi k}{N}).n} \quad \omega_k = \frac{2\pi k}{N}$$

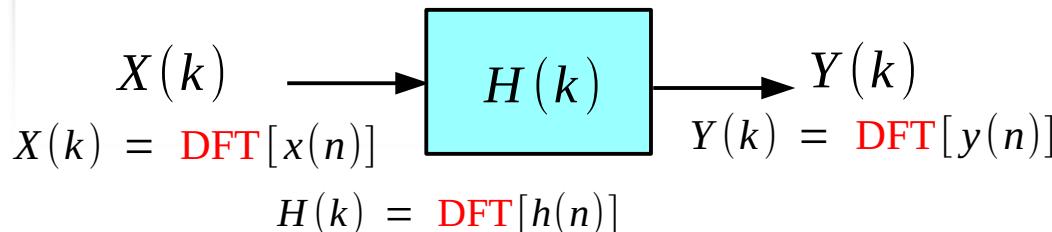
Argument je $e^{j\omega}$ → spekter je zvezen in periodičen s periodo 2π



Določanje izhoda LČN sistema v frekvenčni domeni

- Relacija za določanje izhoda LČN sistema v frekvenčni domeni z uporabo **DFT**

→ Konvolucija v časovni domeni postane množenje v frekvenčni domeni



$$x_1(n) * x_2(n) \leftrightarrow X_1(k) \cdot X_2(k)$$

Spekter izhodnega signala

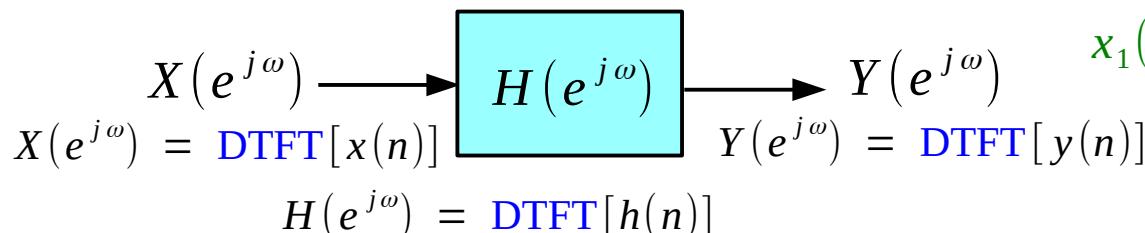
$$Y(k) = H(k) \cdot X(k)$$

Izhodni signal

$$y(n) = \text{IDFT}[Y(k)]$$

- Relacija za določanje izhoda LČN sistema v frekvenčni domeni z uporabo **ČDFT**

→ Konvolucija v časovni domeni postane množenje v frekvenčni domeni



$$x_1(n) * x_2(n) \leftrightarrow X_1(e^{j\omega}) \cdot X_2(e^{j\omega})$$

Spekter izhodnega signala

$$Y(e^{j\omega}) = H(e^{j\omega}) \cdot X(e^{j\omega})$$

Izhodni signal

$$y(n) = \text{IDTFT}[Y(e^{j\omega})]$$



Parametrično modeliranje (avtoregresivni AR parametri)

- **Ocenjevanje močnostnega spektra signala $x(n)$ s parametričnim modeliranjem**
 - Avtoregresivno (AR) modeliranje za izračun močnostnega spektra signala je alternativa metodam, ki temelji na Fourier-jevi transformaciji
 - Parametrično modeliranje omogoča karakterizacijo močnostnih spektrov EEG signalov in njihove dinamike
 - Modeliranje je zmožno razlikovanja med različnimi mentalnimi stanji in zagotavlja kompakten opis različnih EEG ritmov: delta, theta, alfa, mi, beta in gama



Parametrično modeliranje (avtoregresivni AR parametri)

- Ključni spekralni filtri (LDEKK enačba vsebuje samo nerekurzivni člen, $a_k = 0$ ($k = 1, 2, 3, \dots, K$))

$$y(n) = \sum_{m=0}^M b_m x(n-m) + \sum_{k=1}^K a_k y(n-k)$$

- Spekralni filtri:

$$y(n) = \sum_{m=0}^M b_m x(n-m) + \sum_{k=1}^K a_k y(n-k)$$

- Avtoregresivni filtri:

$$y(n) = b_0 x(n) + \sum_{k=1}^K a_k y(n-k)$$

$$x(n) \Leftrightarrow y(n) \Rightarrow x(n) = \sum_{k=1}^K a_k x(n-k) + b_0 y(n)$$

Parametrično modeliranje (avtoregresivni AR parametri)

- **Ocenjevanje močnostnega spektra s parametričnim modeliranjem**

- AR metoda za oceno močnostnega spektra signala $x(n)$ predpostavlja, da je signal $x(n)$ izhod nekega linearnega rekurzivnega (IIR) filtra, ko na njegov vhod pripeljemo signal $v(n)$, ki je beli šum z varianco σ^2 in ravnim močnostnim spektrom (p je red filtra oziroma red modela).

$$x(n) = -\textcolor{red}{a}_1 x(n-1) - \textcolor{red}{a}_2 x(n-2) - \dots - \textcolor{red}{a}_p x(n-p) + v(n)$$

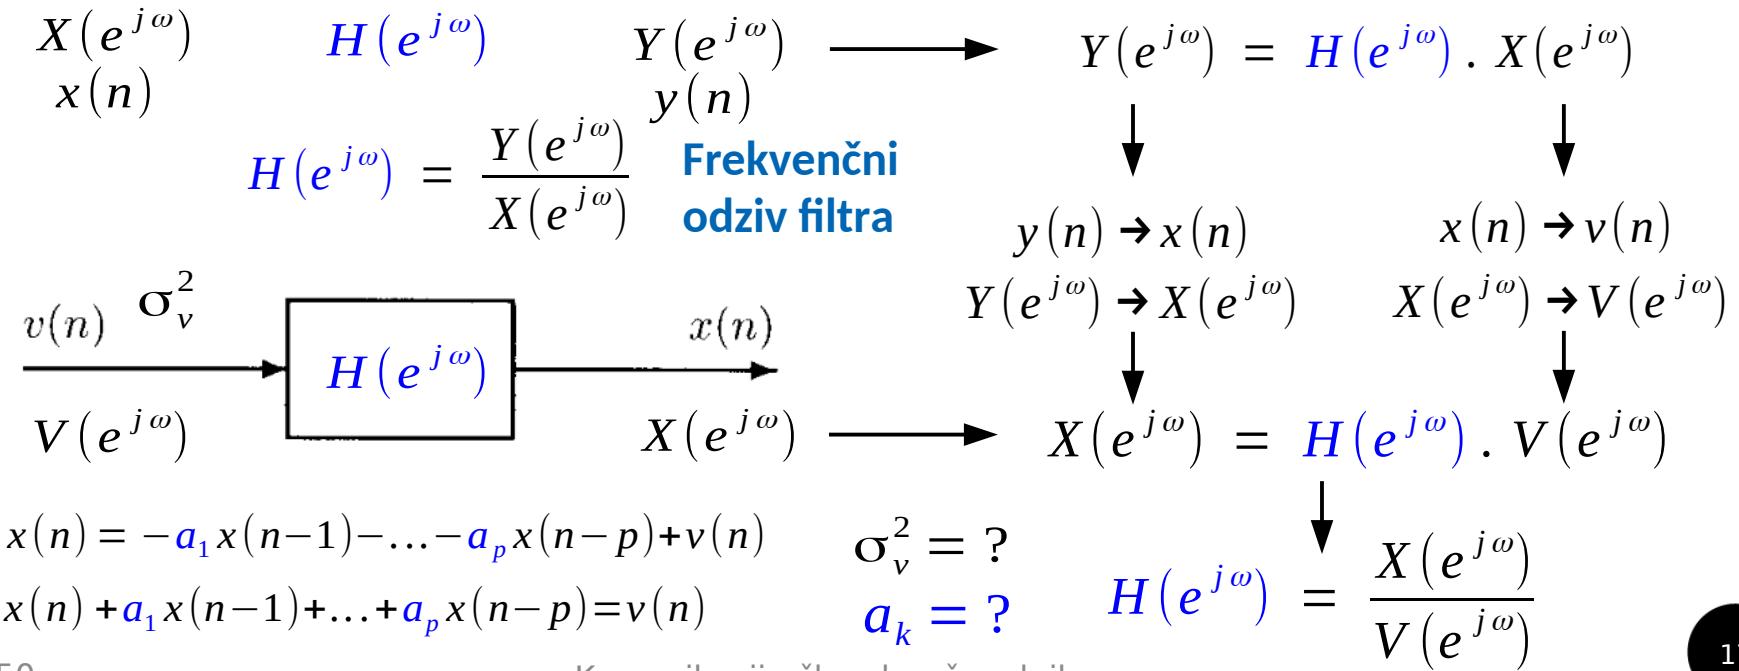
- Ta filter je določen s svojim amplitudnim odzivom $|H(e^{j\omega})|$ in koeficienti $\textcolor{red}{a}_i$
- Kvadrat amplitudnega odziva tega filtra predstavlja močnostni spekter signala $x(n)$
- Koeficienti $\textcolor{red}{a}_1, \textcolor{red}{a}_2, \dots, \textcolor{red}{a}_p$ in σ^2 (parametri modela) določajo močnostni spekter signala $x(n)$

$$H(e^{j\omega}) = \frac{\sigma_v}{1 + \sum_{k=1}^p \textcolor{red}{a}_k e^{-j\omega k}}$$

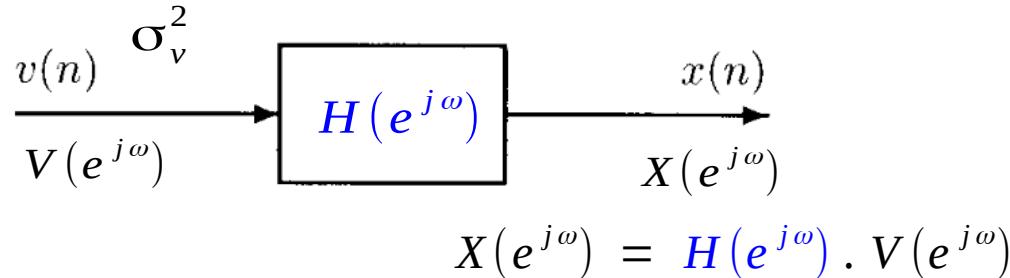
$$|H(e^{j\omega})|^2 = \frac{\sigma_v^2}{\left|1 + \sum_{k=1}^p \textcolor{red}{a}_k e^{-j\omega k}\right|^2}$$

Parametrično modeliranje (avtoregresivni AR parametri)

- AR modeliranje, to je, modeliranje parametrov (koeficientov) IIR filtra, predpostavlja, da je bil modelirani signal $x(n)$ generiran kot rezultat pošiljanja belega šuma $v(n)$ z varianco σ^2_v in ravnim močnostnim spektrom skozi ta IIR filter. Ta linearni IIR filter ima frekvenčni odziv $H(\cdot)$. Opisan je z množico parametrov (koeficientov) in spekralno preoblikuje beli šum tako, da ta doseže ujemanje (približek) s spektrom modeliranega signala $x(n)$. Struktura IIR filtra točno modelira spekter signala $x(n)$ z ostrimi in ločljivimi vrhovi.



Parametrično modeliranje (avtoregresivni AR parametri)



DČFT pari

$$x(n) \leftrightarrow X(e^{j\omega})$$

$$x(n-n_0) \leftrightarrow X(e^{j\omega})e^{-j\omega n_0}$$

$$x_1(n) * x_2(n) \leftrightarrow X_1(e^{j\omega}) \cdot X_2(e^{j\omega})$$

$$x(n) = -a_1 x(n-1) - \dots - a_p x(n-p) + v(n)$$

$$x(n) + a_1 x(n-1) + \dots + a_p x(n-p) = v(n)$$

→

DČFT: $X(e^{j\omega}) + a_1 X(e^{j\omega})e^{-j\omega} + \dots + a_p X(e^{j\omega})e^{-j\omega p} = V(e^{j\omega})$

$$X(e^{j\omega})(1 + a_1 e^{-j\omega} + \dots + a_p e^{-j\omega p}) = V(e^{j\omega})$$

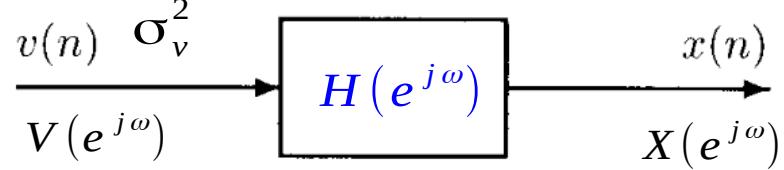
AR model opisan s frekvenčnim odzivom filtra

$$H(e^{j\omega}) = \frac{X(e^{j\omega})}{V(e^{j\omega})} = \frac{1}{1 + \sum_{k=1}^p a_k e^{-j\omega k}}$$

$$\sigma_v^2 = ? \quad a_k = ?$$

Parametrično modeliranje (avtoregresivni AR parametri)

- Frekvenčni odziv AR modela



$$H(e^{j\omega}) = \frac{1}{1 + \sum_{k=1}^p a_k e^{-j\omega k}}$$

$$X(e^{j\omega}) = H(e^{j\omega}) \cdot V(e^{j\omega})$$

Močnostni spekter signala $x(n)$

$$|X(e^{j\omega})|^2 = |H(e^{j\omega})|^2 \cdot |V(e^{j\omega})|^2$$

$$S_v(e^{j\omega}) = |V(e^{j\omega})|^2 = \left| \sum_{n=0}^{N-1} v(n) e^{-j\omega n} \right|^2 = \sigma_v^2$$

$$S_x(e^{j\omega}) = |H(e^{j\omega})|^2 S_v(e^{j\omega})$$

$$S_x(e^{j\omega}) = |X(e^{j\omega})|^2 = \left| \sum_{n=0}^{N-1} x(n) e^{-j\omega n} \right|^2 \longrightarrow S_x(e^{j\omega}) = |H(e^{j\omega})|^2 \sigma_v^2$$

→ parametri modela a_1, \dots, a_p in $\sigma^2 v$

določajo močnostni spekter signala $x(n)$

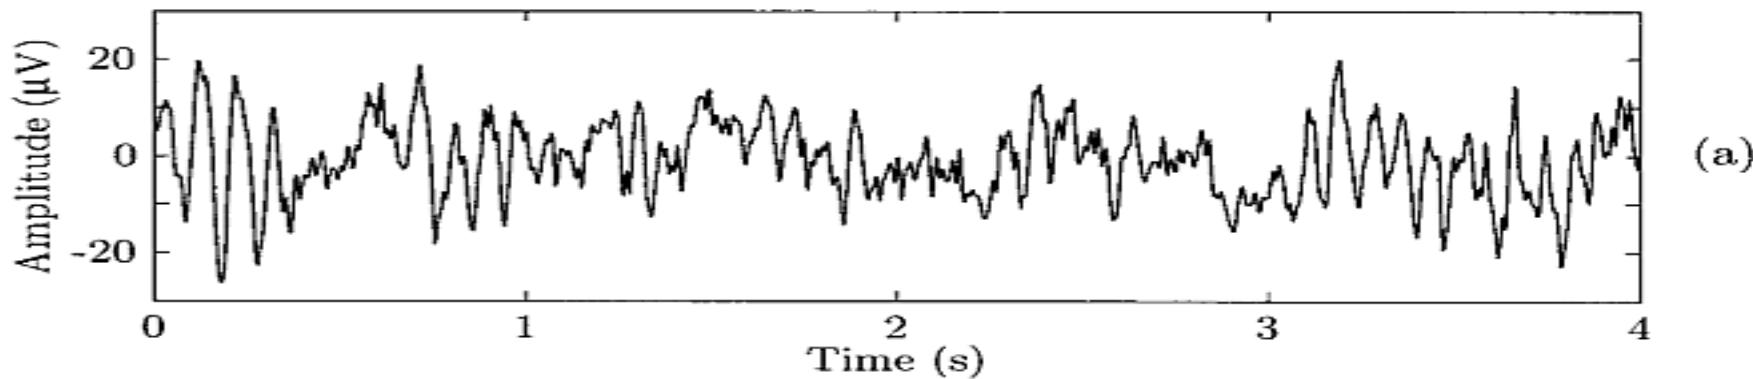
$$S_x(e^{j\omega}) = \frac{\sigma_v^2}{\left| 1 + \sum_{k=1}^p a_k e^{-j\omega k} \right|^2}$$



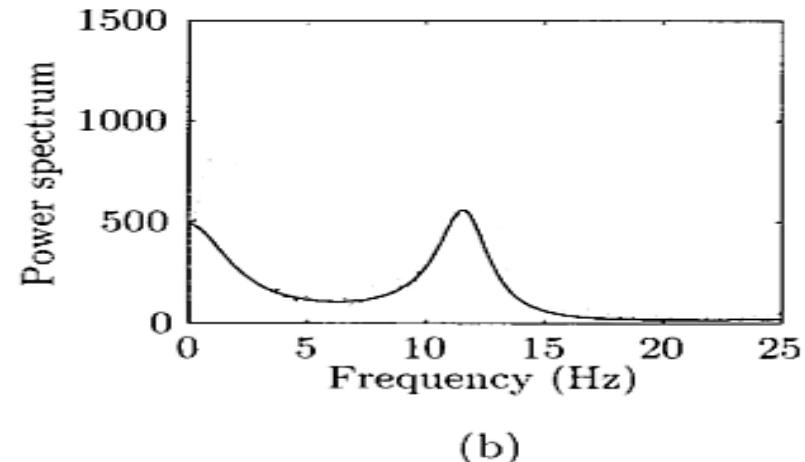
Parametrično modeliranje (avtoregresivni AR parametri)

- **Kako oceniti parametre (koeficiente) modela?**
 - Avtokorelacijske in kovariančne metode za minimizacijo variance napake
 - **Burg-ova** metoda
 - **(Glej: Sornmo, Laguna)**
- Na osnovi parametrov modela a_1, \dots, a_p , in σ^2_v je možno izračunati močnostni spekter AR modela, oziroma **močnostni spekter** signala $x(n)$
- MATLAB:
 - > `[a, e] = arburg(x, p)` % Vrne AR parametre
 - % x - signal, p - red modela
 - % a - parametri modela, e - ocenjena varianca
 - > `pxx = pburg(x, order)` % Vrne močnostni spekter
 - % x - signal, order - red modela
 - % pxx - močnostni spekter

Parametrično modeliranje (avtoregresivni AR parametri)



- (a) Štiri sekundni EEG signal vzorčen s frekvenco vzorčenja 128 smp/sec
- (b) Močnostni spekter kjer je red modela $p = 10$. Parameteri pripadajočega AR močnostnega spektra so bili ocenjeni z Burg-ovo metodo.





Parametrično modeliranje (avtoregresivni AR parametri)

- **Ocenjevanje močnostnega spektra s parametričnim modeliranjem**
 - Parametri AR modela vsebujejo potrebno informacijo ***o spektralni moči in dominantni frekvenci danega EEG ritma***
 - Število vrhov, ki jih je lahko prikazati v AR močnostnem spektru je določeno z redom modela p ; ***vsak naslednji spektralni vrh zahteva povišanje reda modela za dva***
 - Ker je relevantna informacija o spektru shranjena v ***AR parametrih*** (koeficientih filtra), ***so parametri sami kar značilke za klasifikacijo*** zamišljenih motoričnih aktivnosti
 - Modeliranje zagotavlja generacijo močnostnega spektra ***z višjo spektralno resolucijo*** kot Fourier-jeva analiza, kar je še posebaj pomembno med ***analizo krajsih segmentov signalov***
 - ***Krajsi segmenti signalov so nujni zaradi zahtevanega tekočega ažuriranja značilk ozziroma analize v (navidezno) relanem času***

Parametrično modeliranje (avtoregresivni AR parametri)

- (a) EEG signal z izrazitim alfa ritmom
- (b) Simulirani signal dobljen z AR modelom katerega parametri so bili ocenjeni preko signala pod (a)

